



## ENJEUX ET DÉFIS DES DONNÉES GÉOSPATIALES POUR L'ONCOLOGIE

GROUP GEOCANCER



# Etude de biais sur les adresses de patients hospitalisés à l'HEGP et l'Institut Curie

Joséphine Bocquet – Ingénierie Géomaticienne



# Enjeux et défis des données géospatiales pour l'oncologie

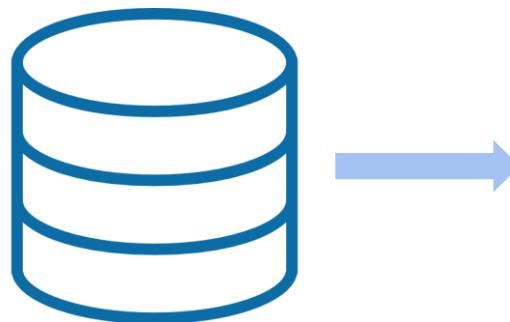


Ensemble des adresses et cartes présentés sont des **données simulées**  
pour préserver la confidentialité des patients



# Enjeux et défis des données géospatiales pour l'oncologie

Objectif : Géolocalisation des adresses patients pour enrichir les données de santé avec des éléments annexes



ID Patient	Adresse patient	Autres données ...
1	20 rue Leblanc 75015 Paris	...
2	10 rue des Terres au Curé 75013 Paris	...

Entrepôt de  
données de santé

Exemple de table extraites de l'entrepôt

# Enjeux et défis des données géospatiales pour l'oncologie

Objectif : **Géolocalisation** des adresses patients pour enrichir les données de santé avec des éléments annexes

ID Patient	Adresse patient
1	20 rue Leblanc 75015 Paris
2	10 rue des Terres au Curé 75013 Paris



x Environ 2 millions de patients

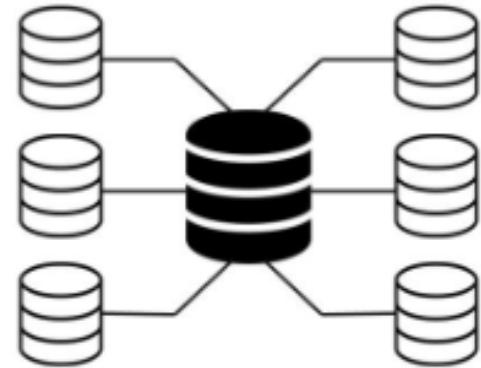
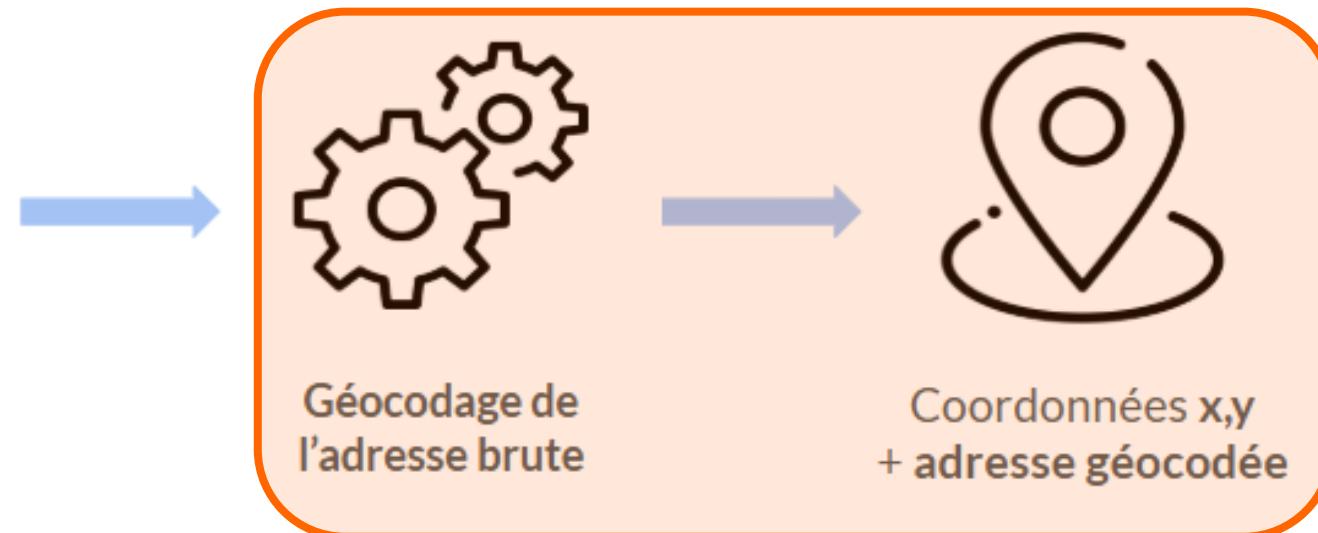


# Enjeux et défis des données géospatiales pour l'oncologie

Objectif : **Géolocalisation** des adresses patients pour enrichir les données avec des éléments annexes



Adresse brute  
indiquée dans le  
dossier patient



Croisement avec des  
données annexes

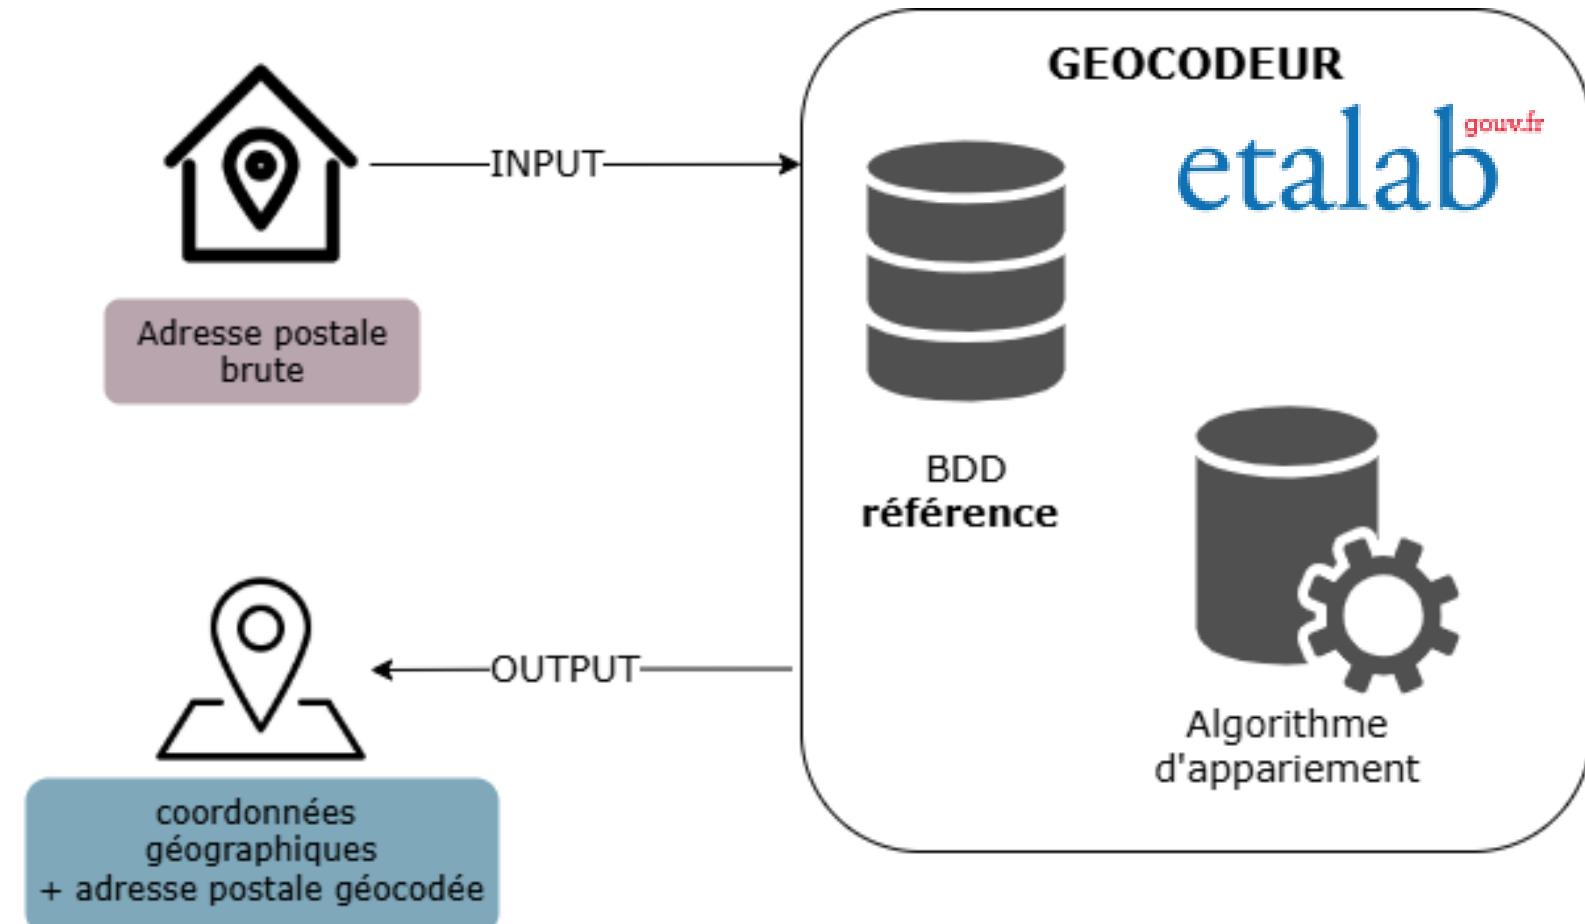
Problématique : **Qualité** des adresses fournies par les patients

# Des données géographiques à l'hôpital

## Géocodage

Adresse initiale

10 rue des Terres au Curé  
75013 Paris



# Des données géographiques à l'hôpital

## Géocodage

### Adresse initiale

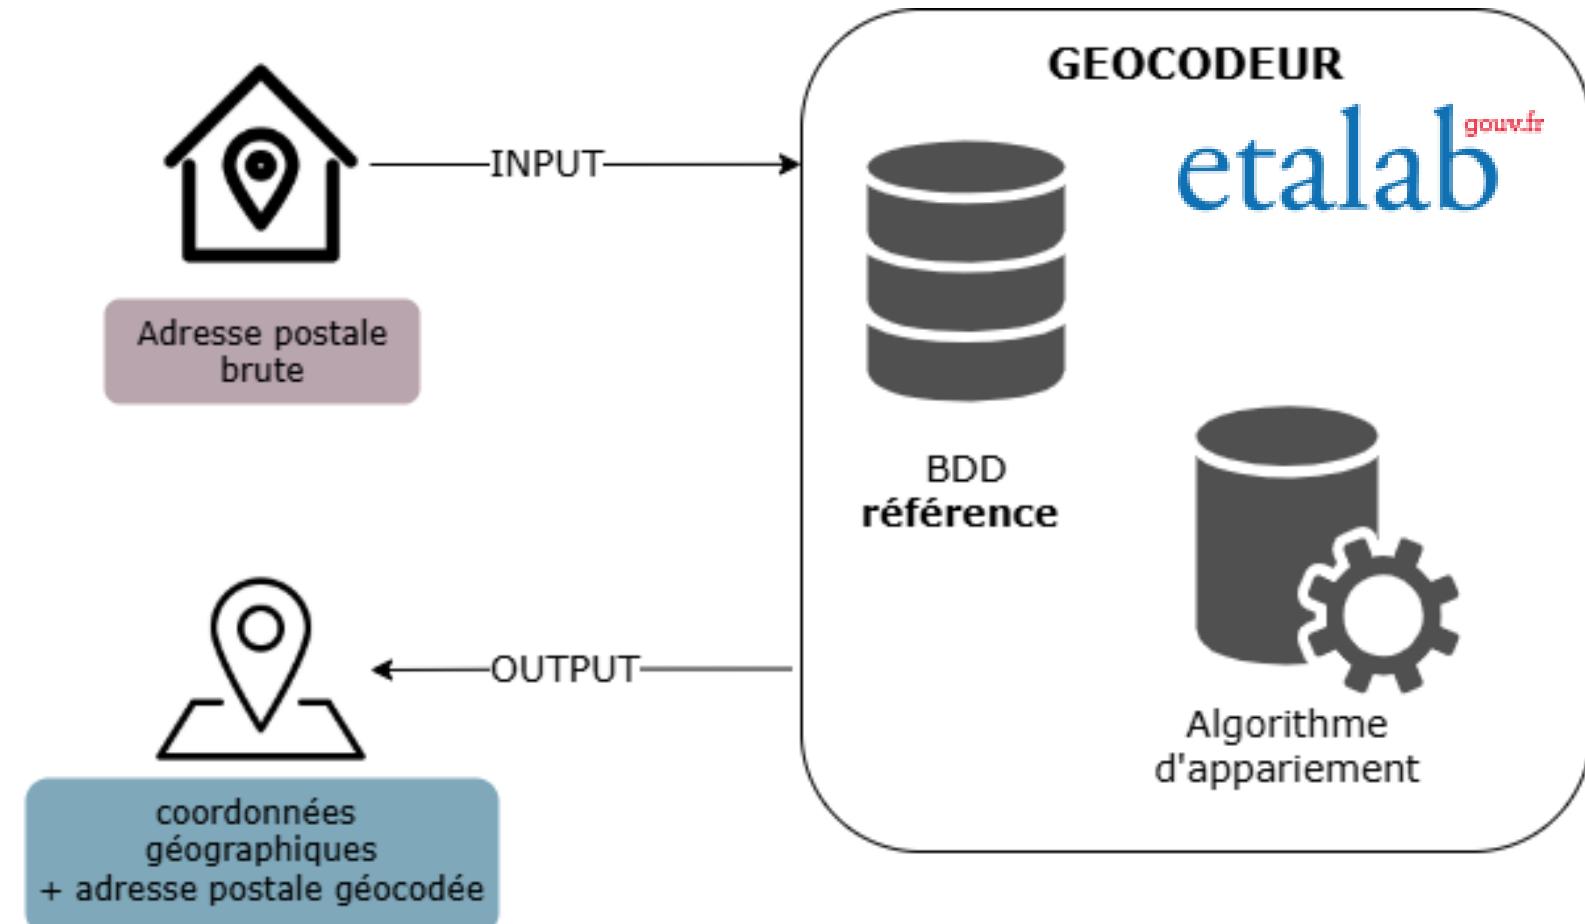
10 rue des Terres au Curé  
75013 Paris

### Adresse géocodée

10 rue des Terres au Curé  
75013 Paris

### Coordonnées géographiques

y : 48.82413102561786  
x : 2.372370381468407



*Schématisation du fonctionnement d'un géocodieur*



# Des données géographiques à l'hôpital

**Problématique :** Qualité des adresses fournies par les patients

## Adresses postales correctes :

- Eléments additionnels (Esc, Appt, Bâtiment, etc.)
- Adresse administrative camouflée

## Adresses postales incorrectes :

- Adresses relatives (« Chez Mr », etc.)
- Libellé administratif (Centre hospitalier, pénitentiaires, etc.)



# Des données géographiques à l'hôpital

## *Exemples d'adresses retrouvées :*

Pour l'adresse : **10 rue des Terres au Curé 75013 Paris**

On peut trouver des erreurs du type :

Eléments additionnels

**Appartement T Bat C 10 rue des Terres au Curé 75013 Paris**



# Des données géographiques à l'hôpital

## *Exemples d'adresses retrouvées :*

Pour l'adresse : **10 rue des Terres au Curé 75013 Paris**

On peut trouver des erreurs du type :

Eléments additionnels

**Appartement T Bat C 10 rue des Terres au Curé 75013 Paris**

Libellé administratifs

**Maison des Associations de Solidarité 75013 Paris**



# Des données géographiques à l'hôpital

## *Exemples d'adresses retrouvées :*

Pour l'adresse : **10 rue des Terres au Curé 75013 Paris**

On peut trouver des erreurs du type :

Eléments additionnels

**Appartement T Bat C 10 rue des Terres au Curé 75013 Paris**

Libellé administratifs

**Maison des Associations de Solidarité 75013 Paris**

Adr. administrative camouflée

**10 rue des Terres au Curé 75013 Paris**



# Des données géographiques à l'hôpital

**Problématique :** Qualité de l'écriture des adresses

Adresses postales correctes :

Eléments additionnels

Adr. administrative camouflée

Adresses postales incorrectes :

Libellé administratifs

Adresses relatives

On retrouve donc **2 types de biais** : des **biais textuels** et des **biais géographiques**



# Des données géographiques à l'hôpital

**Problématique :** Qualité de l'écriture des adresses

Adresses postales correctes :

Eléments additionnels

Adr. administrative camouflée

Adresses postales incorrectes :

Libellé administratifs

Adresses relatives

Adresses géocodables

On retrouve donc **2 types de biais** : des **biais textuels** et des **biais géographiques**



# Identification des biais textuels

## Exemple

### 1 . RAW DATA

raw address : Hopital Europeen George Pompidou 20 rue Leblanc

geocoded address : 20 rue Leblanc

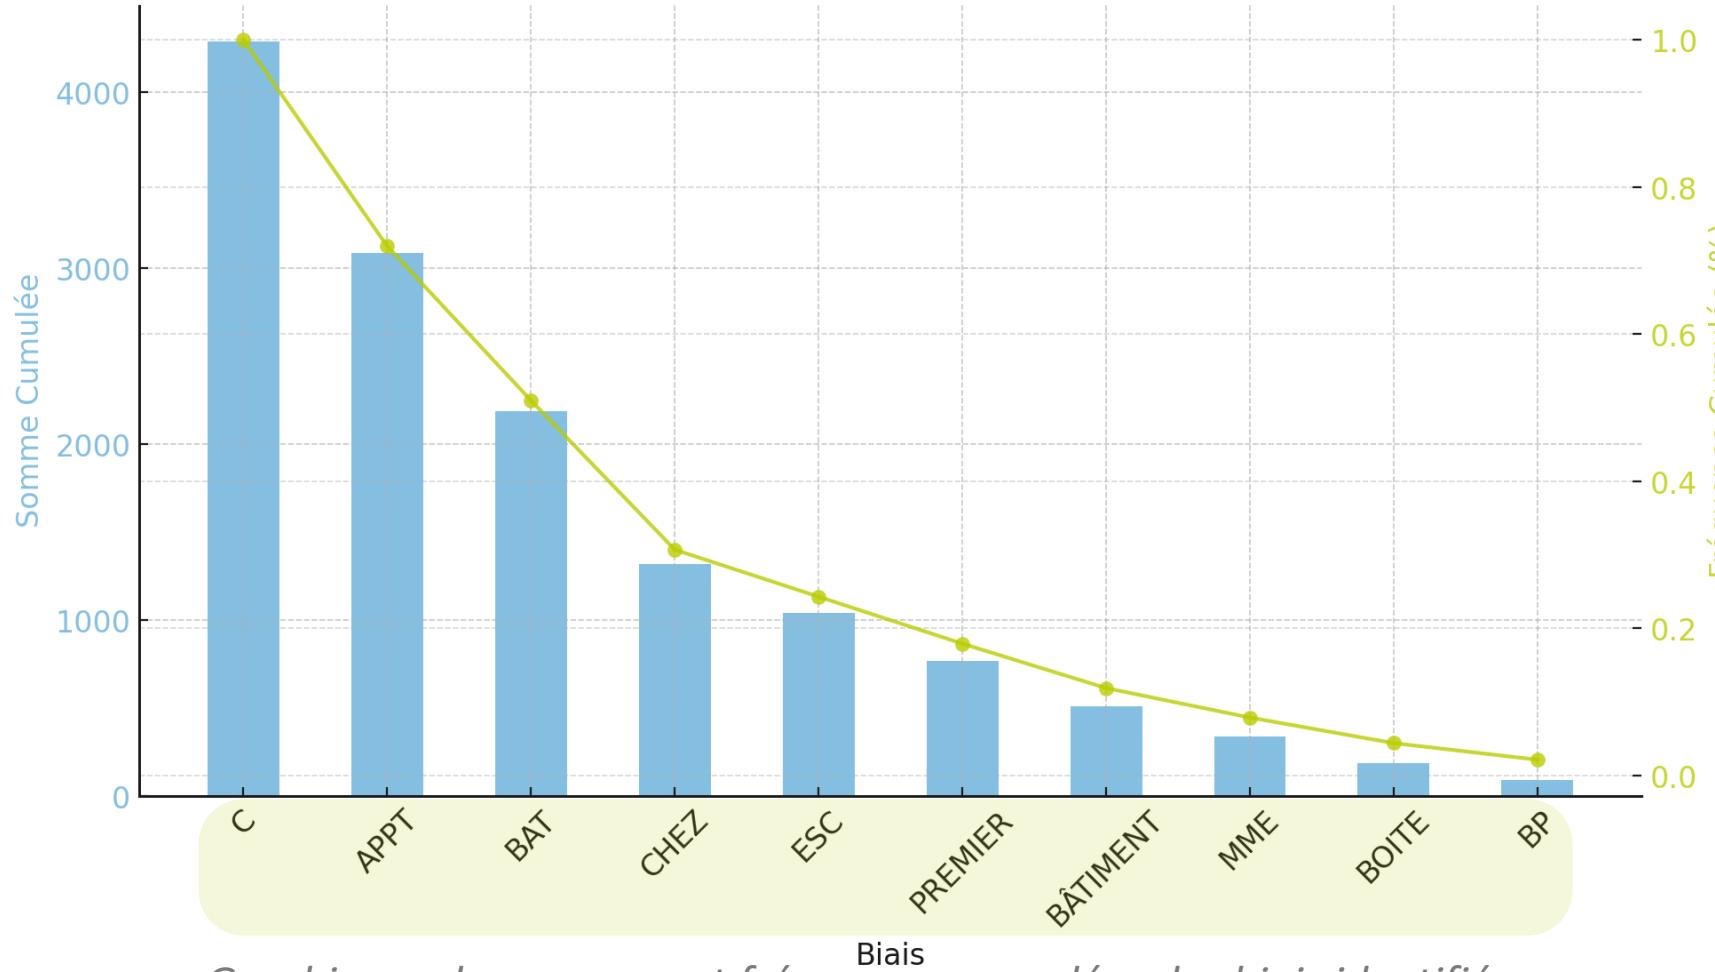
### 2. SEQUENCE ALIGNMENT

Hopital HEGP 20 rue Leblanc  
-----20 rue Leblanc



# Identification des biais textuels

Résultat : 10 éléments additionnels les plus fréquents

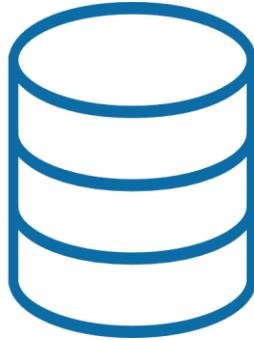


Les 10 biais identifiés sont présents dans :

**4397** adresses  
soit **0.238 %**

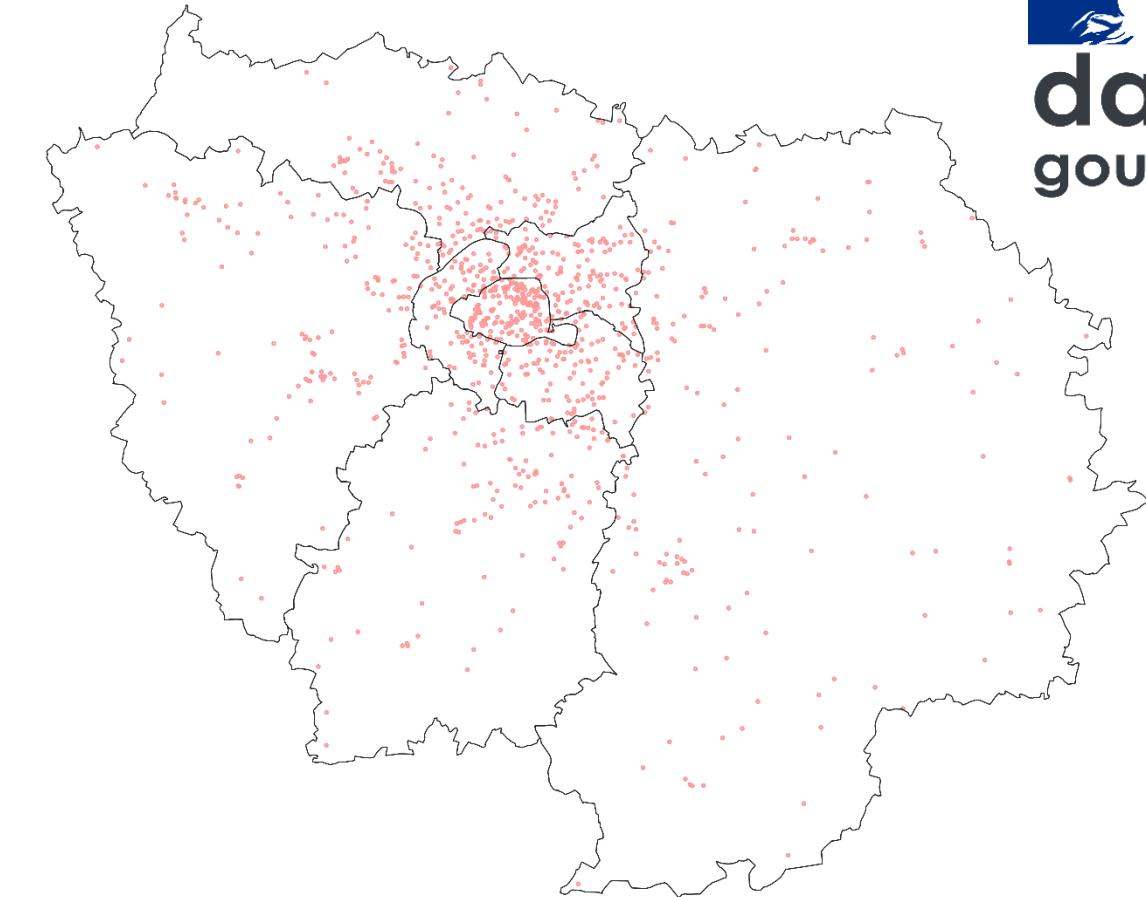


# Simulation de biais sur des données de références



Adresse et coordonnées  
des écoles

Adresse école	Coordonnées x,y
17 rue Auguste Compte 75006 Paris	x : 2.3348 y : 48.8443



Répartition de mille écoles du premier et second degrés  
en Île-de-France

# Simulation de biais sur des données de références



Intégration des biais



Adresse et coordonnées  
de référence

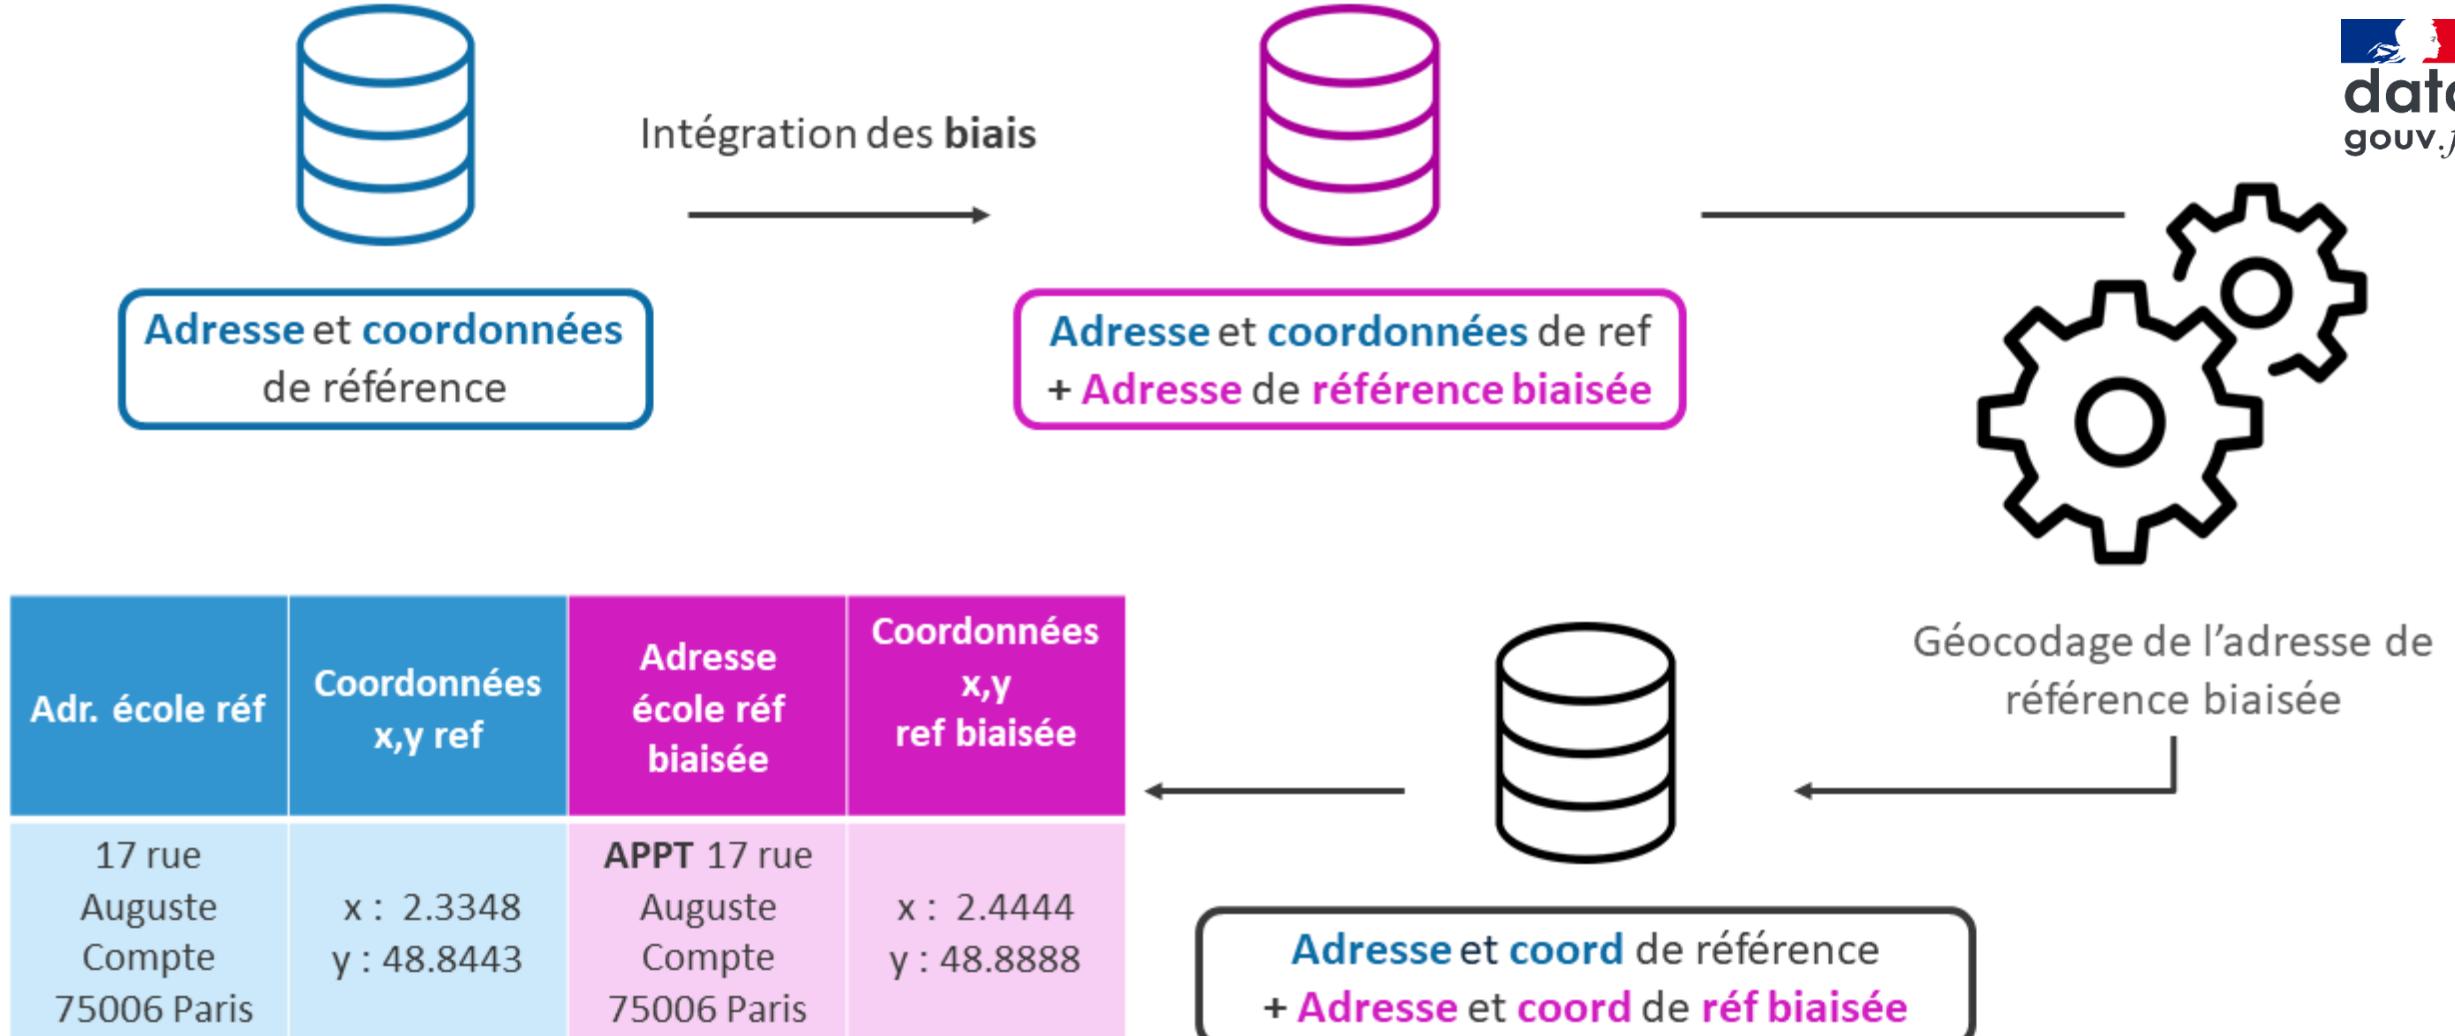
Adresse et coordonnées de ref  
+ Adresse de référence biaisée

Adresse école réf	Coordonnées ref x,y
17 rue Auguste Compte 75006 Paris	x : 2.3348 y : 48.8443

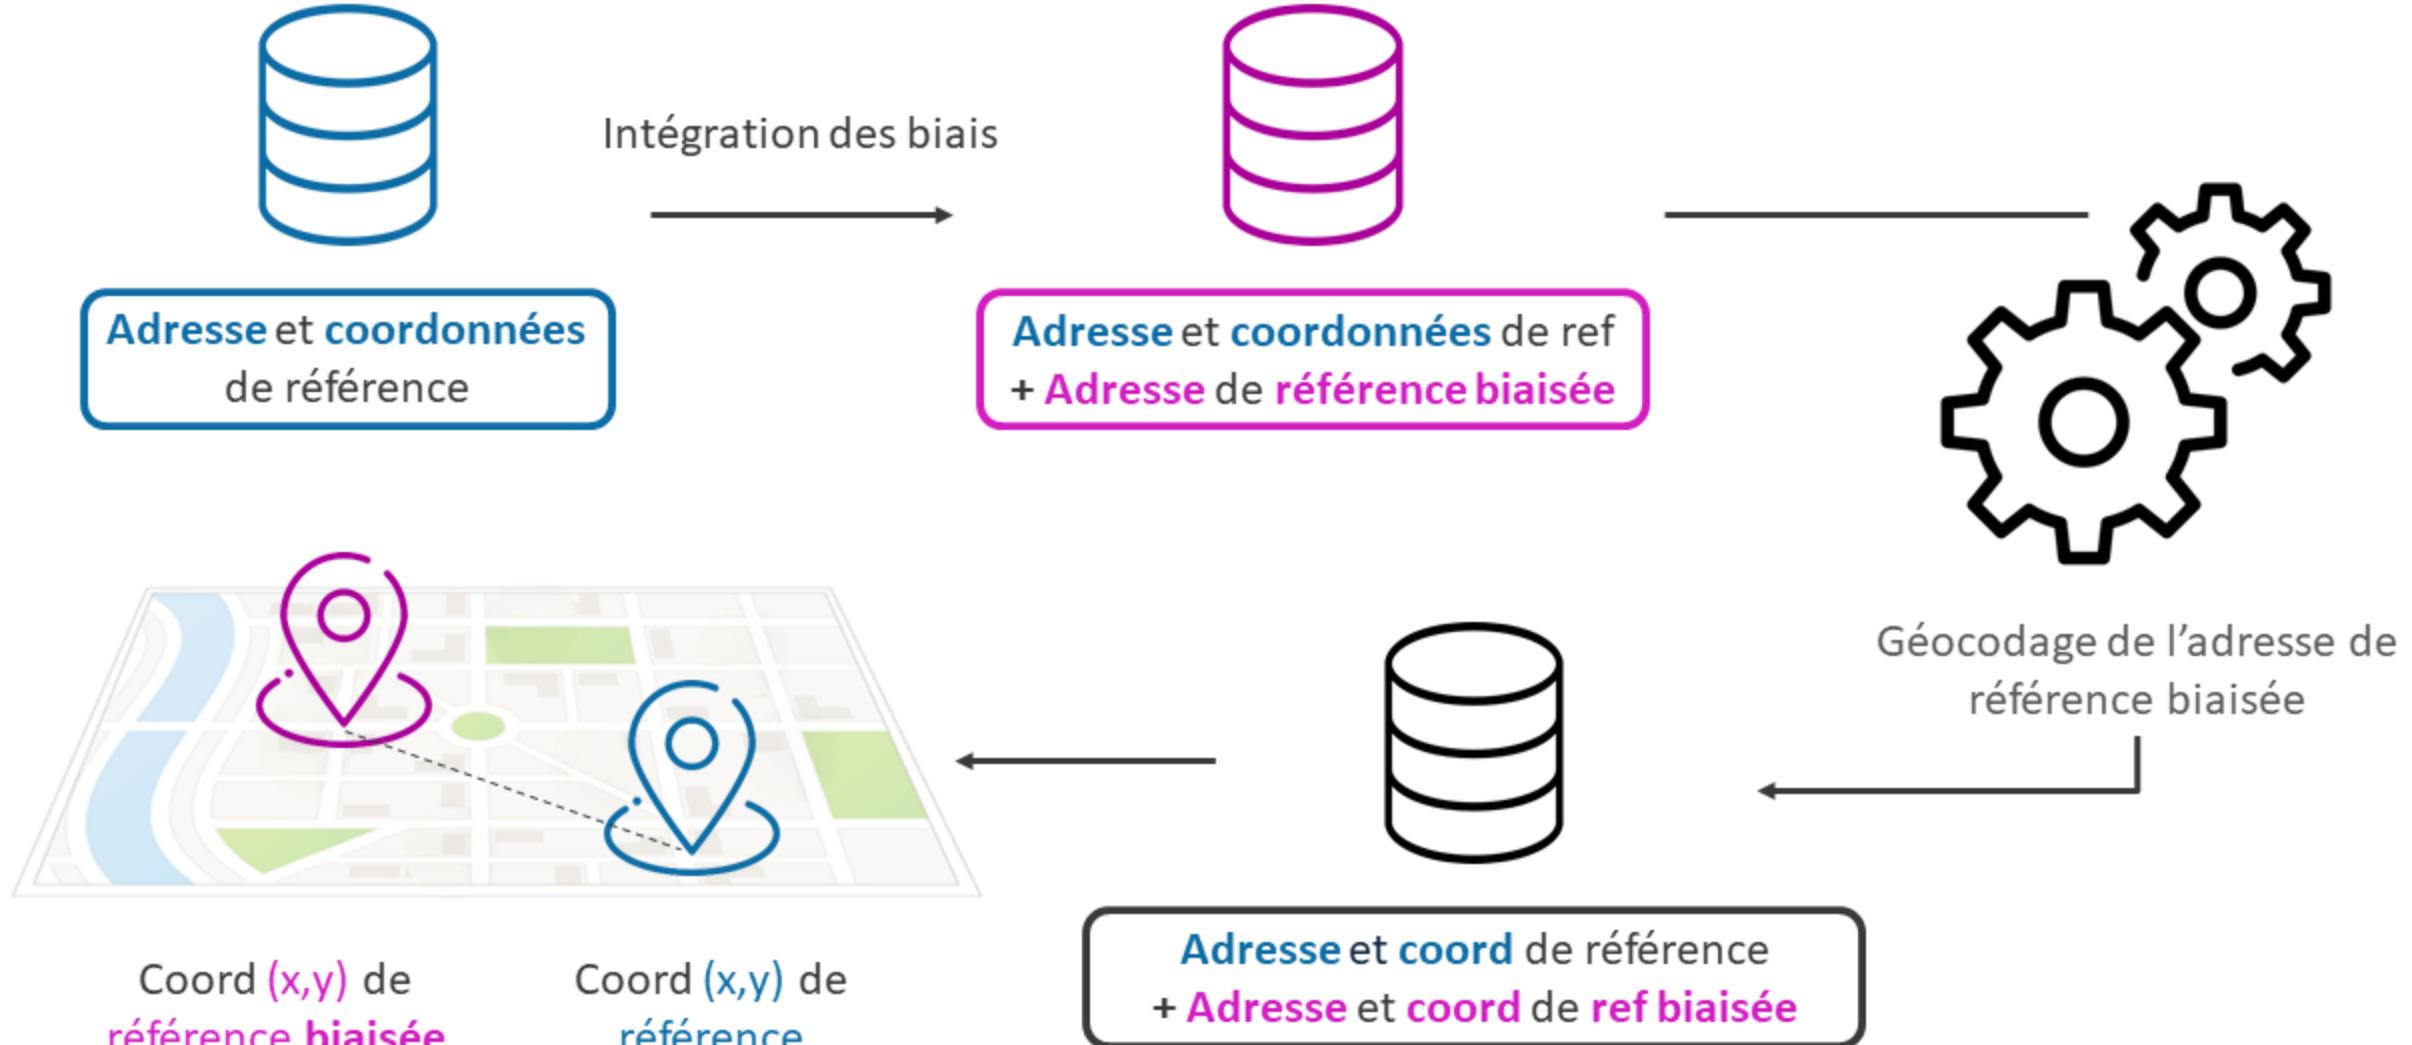
Adresse école réf	Coordonnées ref x,y	Adresse école réf biaisée
17 rue Auguste Compte 75006 Paris	x : 2.3348 y : 48.8443	APPT 17 rue Auguste Compte 75006 Paris



# Simulation de biais sur des données de références



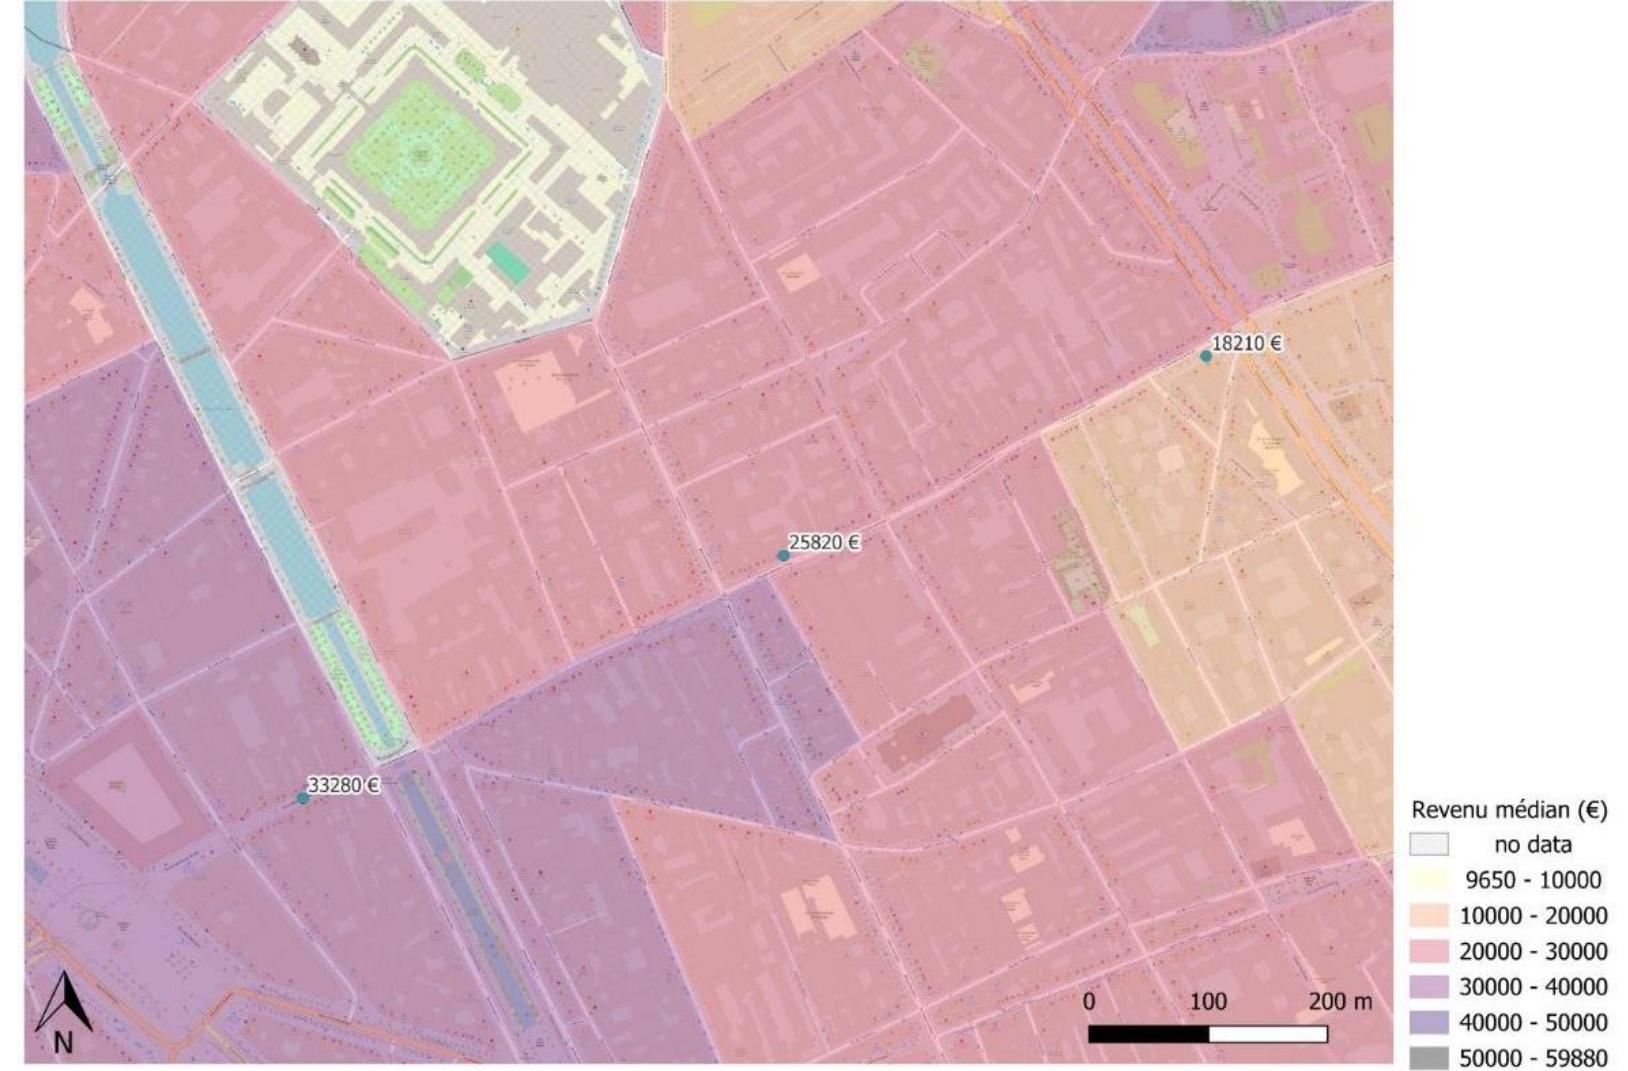
# Simulation de biais sur des données de références



# Simulation de biais sur des données de références

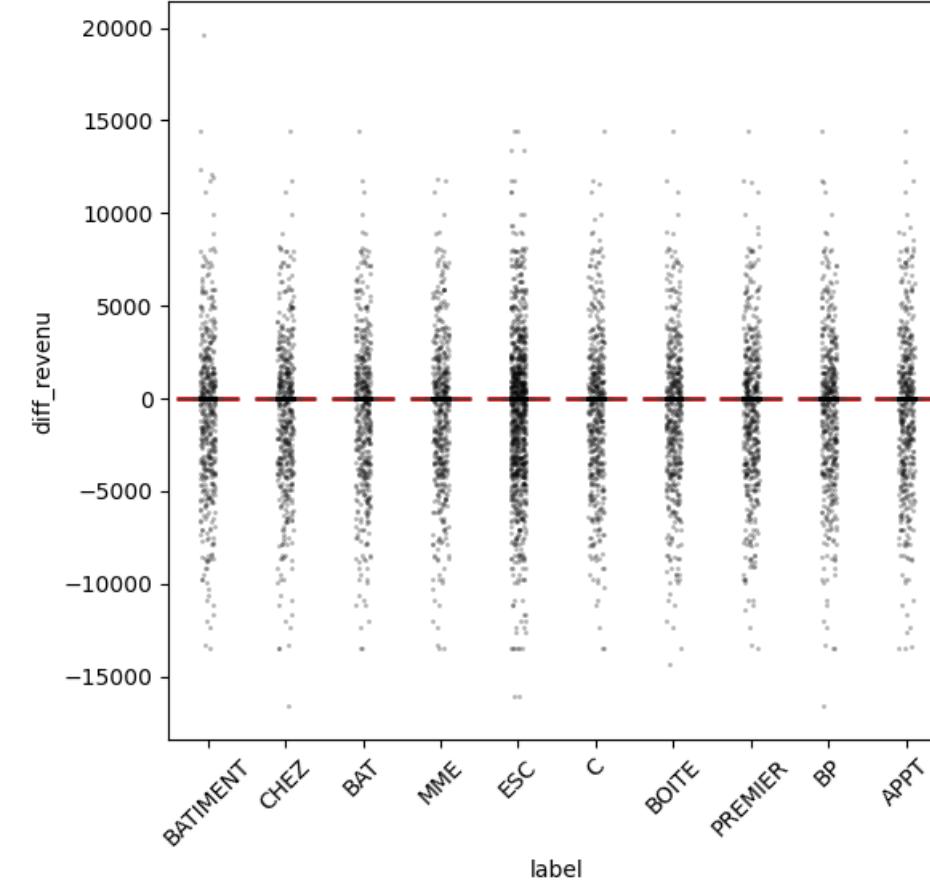
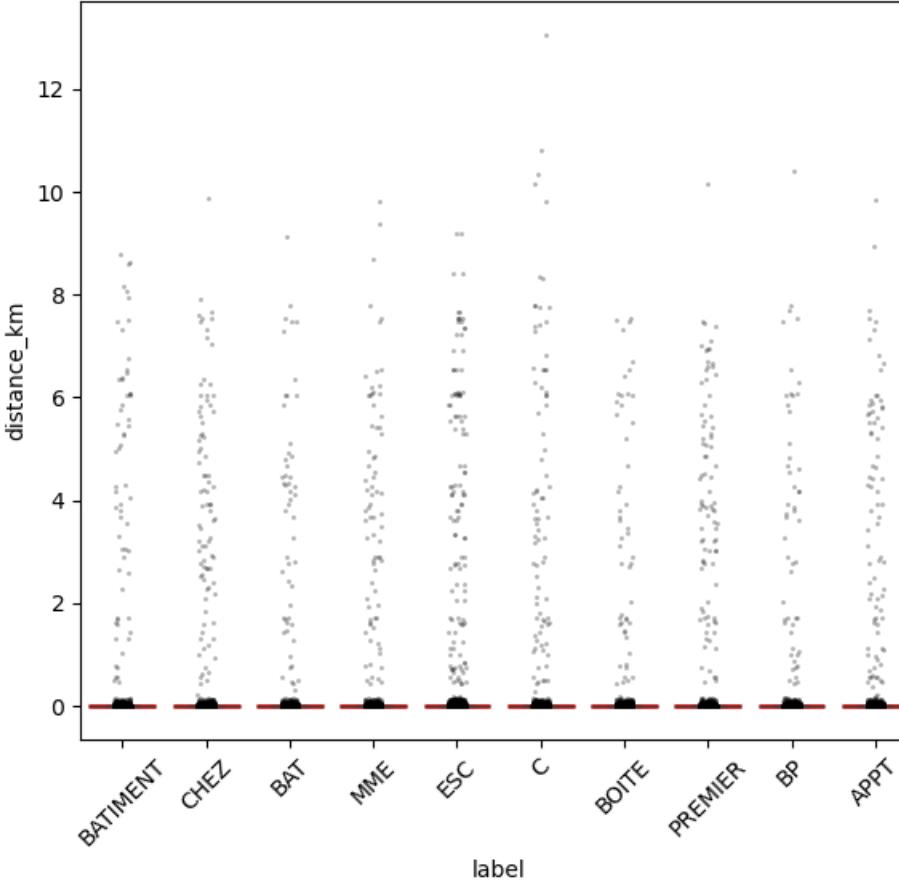
*Mesure de l'impact  
sur des données  
socioéconomiques*

*Distribution du revenu  
médian par unité de  
consommation le long  
de la rue du Faubourg  
Saint Antoine*





# Simulation de biais sur des données de références



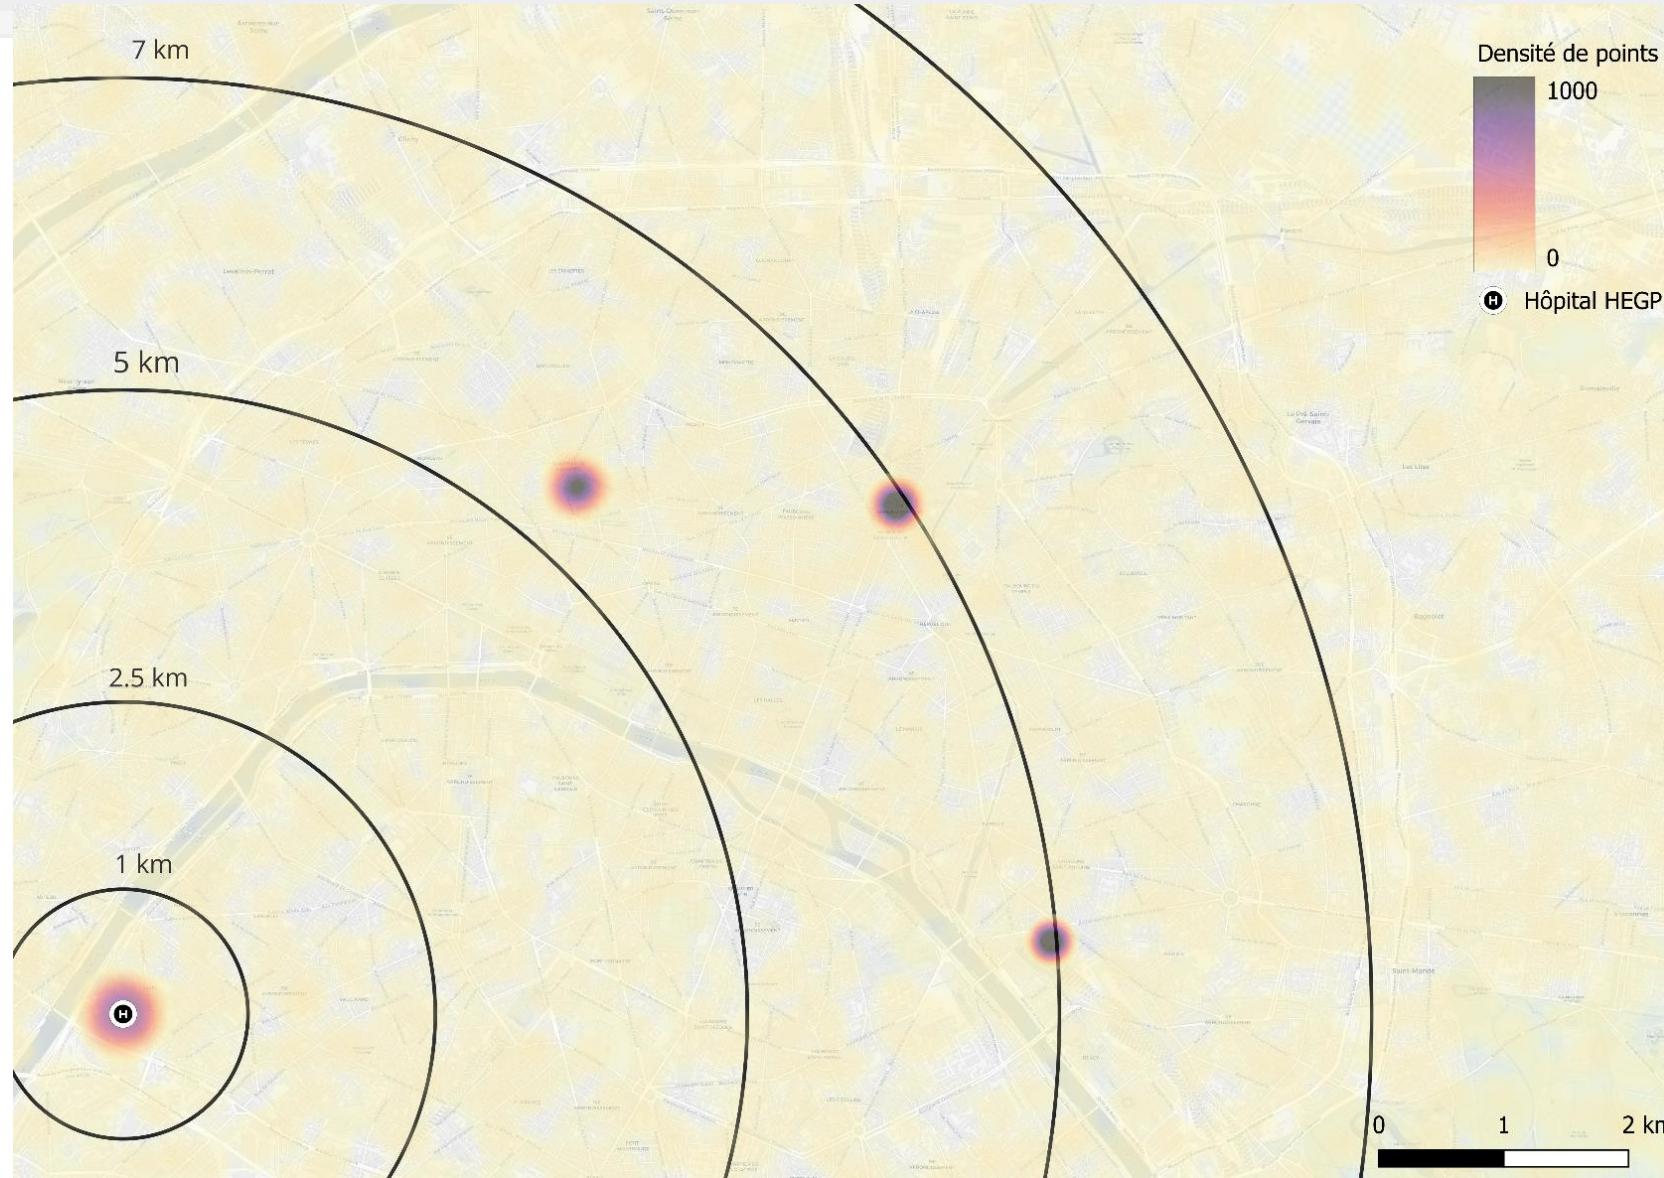
## Conclusion

Géocodeur très **robuste** aux éléments additionnels

Figures de la distance (à gauche) et différence de revenu (à droite) entre les coordonnées de références et les coordonnées de référence biaisées



# Identification des biais géographiques



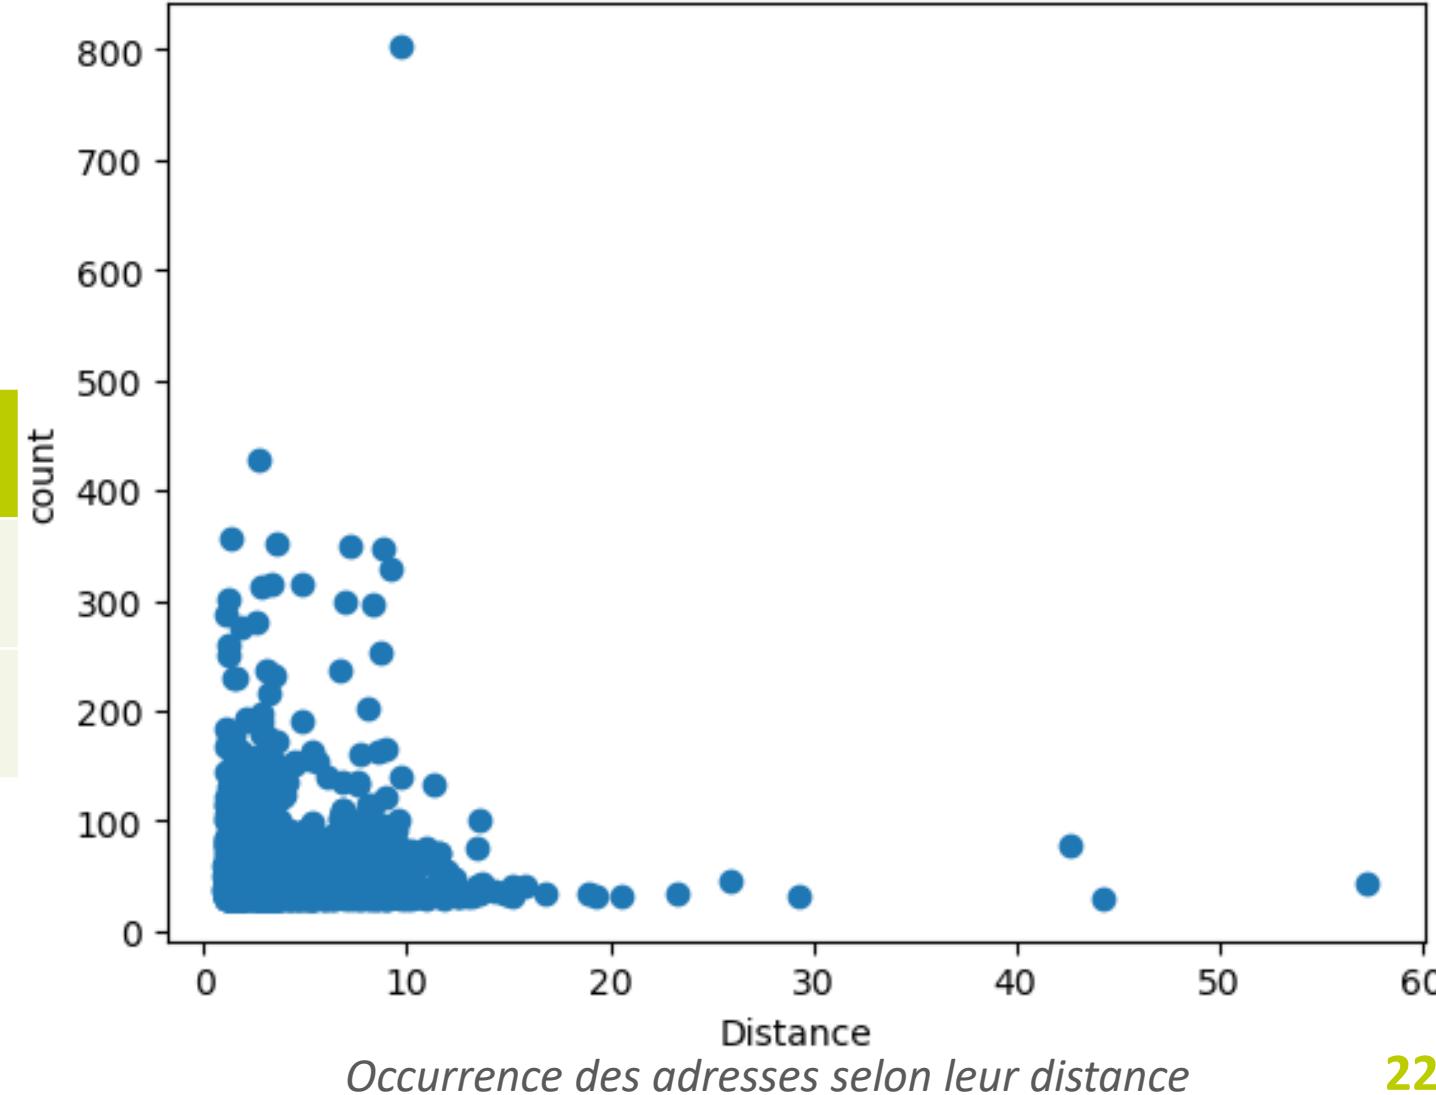
Répartition  
d'une  
simulation de  
jeux de données  
comportant des  
« hot spot »  
d'adresses  
administratives

# Identification des biais géographiques

## Méthode :

### 1. Filtre sur les adresses pertinentes

	Occurrence
Adresses différentes	788 765
1. Après filtre	2404

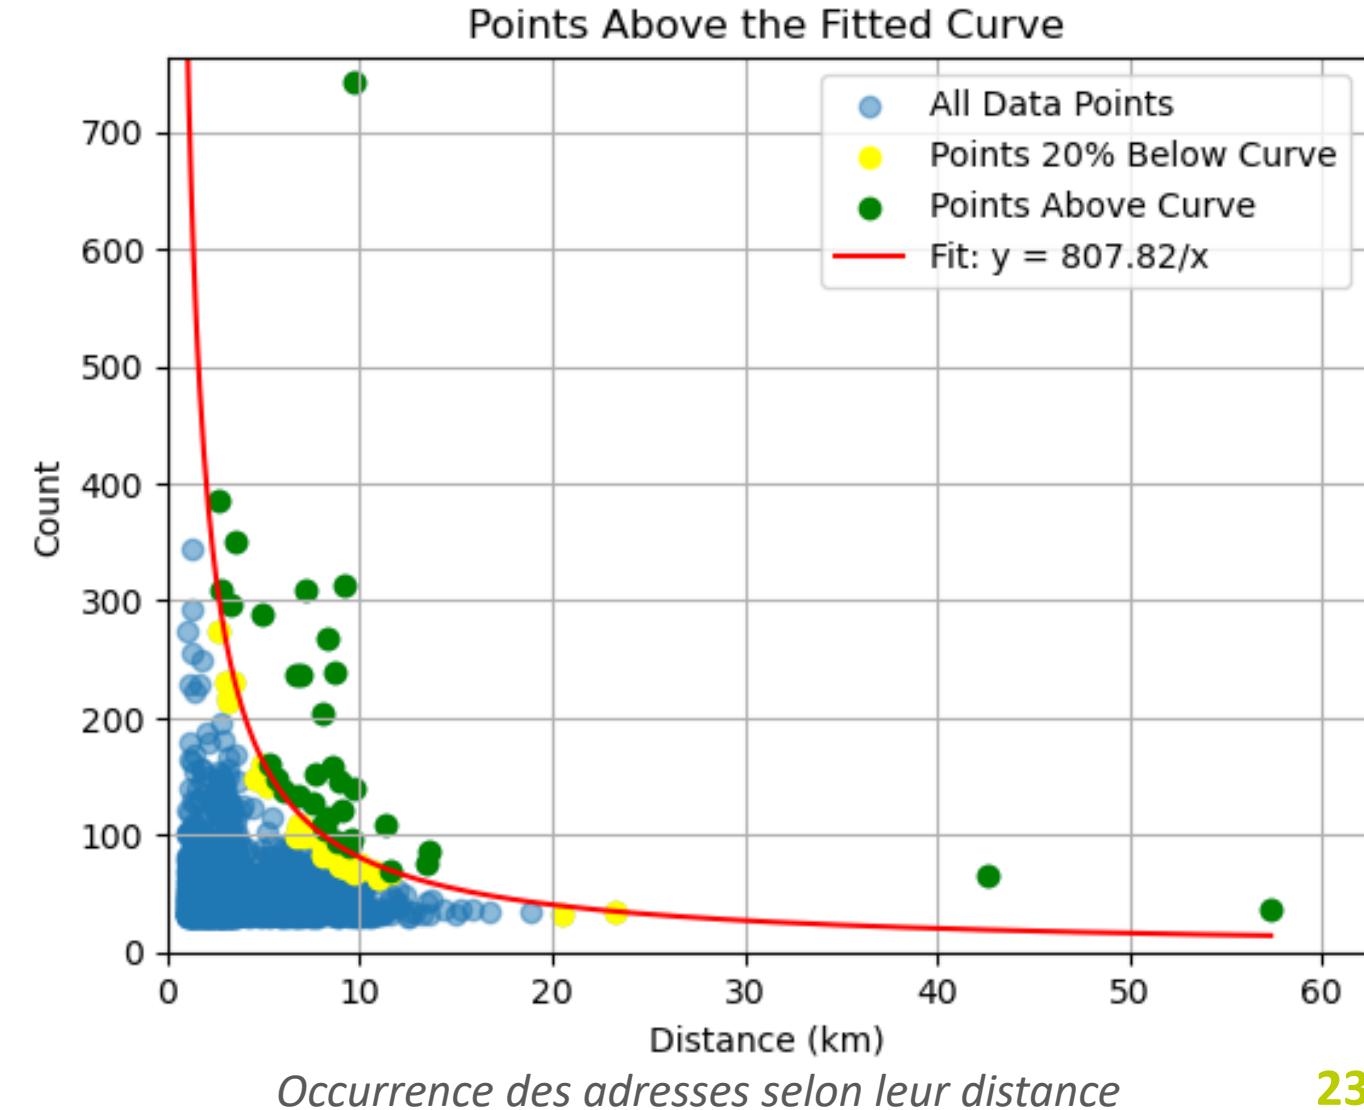


# Identification des biais géographiques

## Méthode :

### 2. Régression statistique

	Occurrence
Adresses différentes	788 765
1. Après filtre	2404
2. Après régression (80% de la valeur attendue)	64



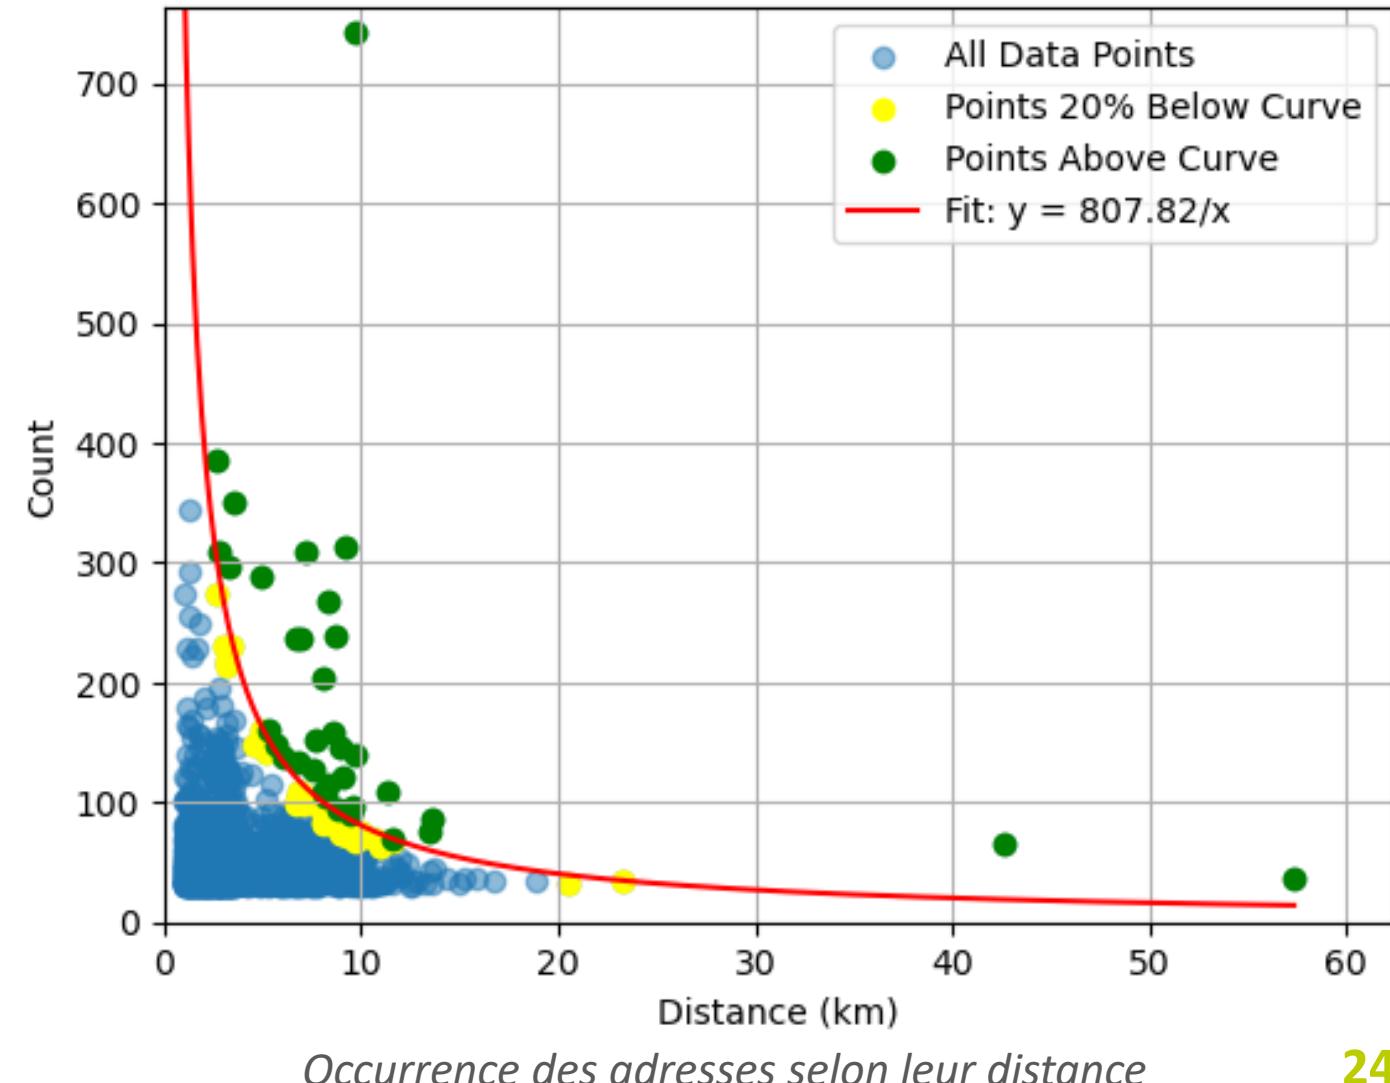
# Identification des biais géographiques

Sur les 64 adresses identifiées,  
**45 sont des biais géographiques**

soit **0.42 %** de l'ensemble  
 des adresses postales correctes

## Perspectives

Amélioration processus pour  
 détecter **faux positifs**





# Enjeux et défis des données géospatiales pour l'oncologie

## Conclusion

### *Des données géographiques à l'hôpital*

La qualité de la donnée géographique est associées aux questions de parcours thérapeutique du patient – dépistage, soin, retour au travail etc. Mais aussi car les facteurs socioéconomiques et d'expositions ont un impact sur le cancer.

### *Des biais dans les données*

L'identification des biais dans les adresses permet d'identifier les patients en grande précarité sociale, moins bien dépisté, afin d'adapter des plans de traitements.

### *Consolider la captation d'adresses*

Qualité des données géographiques à travers un suivi spatio-temporelle des patients  
– Nécessité des partenariat (CPAM , CHU, ... )



JEUDI 3 AVRIL 2025

MAS Paris, 13e

10 rue des terres au curé

# ENJEUX ET DÉFIS DES DONNÉES GÉOSPATIALES POUR L'ONCOLOGIE

GROUP GEOCANCER



Merci pour votre  
écoute

Joséphine Bocquet – Ingénierie Géomaticienne